12 | Java编译器（四）：去除语法糖和生成字节码

2020-06-29 宫文学

编译原理实战课 进入课程 >

讲述：宫文学
时长 19:35　大小 17.94M

你好，我是宫文学。今天是 Java 编译器的最后一讲，我们来探讨编译过程最后的两个步骤：**去除语法糖和生成字节码。**

其实今天要讲的这两个编译步骤，总体上都是为生成字节码服务的。在这一阶段，编译器首先会把语法糖对应的 AST，转换成更基础的语法对应的 AST，然后基于 AST 和符号表，来生成字节码。

从 AST 和符号表，到变成字节码，这可是一个很大的转变，就像把源代码转化成 AST 一样。**那么，这个过程的实现思路是什么？有什么难点呢？**

今天这一讲，我们就一起来解决以上这些问题，在这个过程中，你对 Java 编译器的认识会变得更加完整。

好了，我们首先来看看去除语法糖这一处理步骤。

去除语法糖（Syntactic Sugar）

Java 里面提供了很多的语法糖，比如泛型、Lambda、自动装箱、自动拆箱、foreach 循环、变长参数、内部类、枚举类、断言（assert），等等。

你可以这么理解语法糖：它就是提高我们编程便利性的一些语法设计。既然是提高便利性，那就意味着语法糖能做到的事情，用基础语法也能做到，只不过基础语法可能更啰嗦一点儿而已。

不过，我们最终还是要把语法糖还原成基础语法结构。比如，foreach 循环会被还原成更加基础的 for 循环。那么，问题来了，**在编译过程中，究竟是如何去除语法糖的？基础语法和语法糖又有什么区别呢？**

在第 10 讲中，我提到过，在 JDK14 中，去除语法糖涵盖了编译过程的四个小阶段。

TRANSTYPES：泛型处理，具体实现在 TransTypes 类中。

TRANSPATTERNS：处理模式匹配，具体实现在 TransPattern 类中。

UNLAMBDA：把 LAMBDA 转换成普通方法，具体实现在 LambdaToMethod 类中。

LOWER：其他所有的语法糖处理，如内部类、foreach 循环、断言等，具体实现在 Lower 类中。

以上去除语法糖的处理逻辑都是相似的，它们的**本质都是对 AST 做修改和变换**。所以，接下来我挑选了两个比较有代表性的语法糖，泛型和 foreach 循环，和你分析它们的处理过程。

首先是对泛型的处理。

Java 泛型的实现比较简单，`LinkedList<String>`和`LinkedList`对应的字节码其实是一样的。泛型信息`<String>`，只是用来在语义分析阶段做类型的检查。检查完之后，这些类型信息就会被去掉。

所以，Java 的泛型处理，就是把 AST 中与泛型有关的节点简单地删掉（相关的代码在 TransTypes 类中）。

对于“`List<String> names = new ArrayList<String>()`”这条语句，它对应的 AST 的变化过程如下，其中，橙色的节点就是被去掉的泛型。

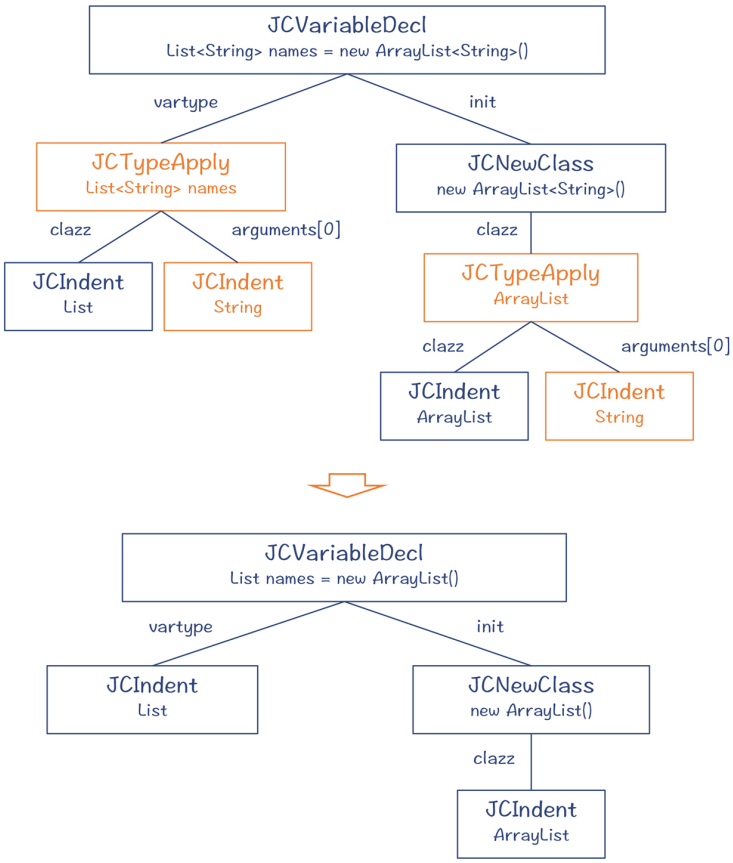

图 1：对泛型的处理

然后，我们分析下对 foreach 循环的处理。

foreach 循环的意思是“遍历每一个成员”，它能够以更简洁的方式，遍历集合和数组等数据结构。在下面的示例代码中，foreach 循环和基础 for 循环这两种处理方式的结果是等价的，但你可以看到，foreach 循环会更加简洁。

复制代码

```
1 public static void main(String args[]) {
2     List<String> names = new ArrayList<String>();
3     ...
4     //foreach循环
5     for (String name:names)
```

```
        System.out.println(name);


    //基础for循环
    for ( Iterator i = names.iterator(); i.hasNext(); ) {
        String name = (String)i.next();
        System.out.println(name);
    }

```

Java 编译器把 foreach 循环叫做**增强 for 循环**，对应的 AST 节点是**JCEnhancedForLoop**。

针对上面的示例代码，我们来对比一下增强 for 循环的 AST 和去除语法糖之后的 AST，如下图所示：

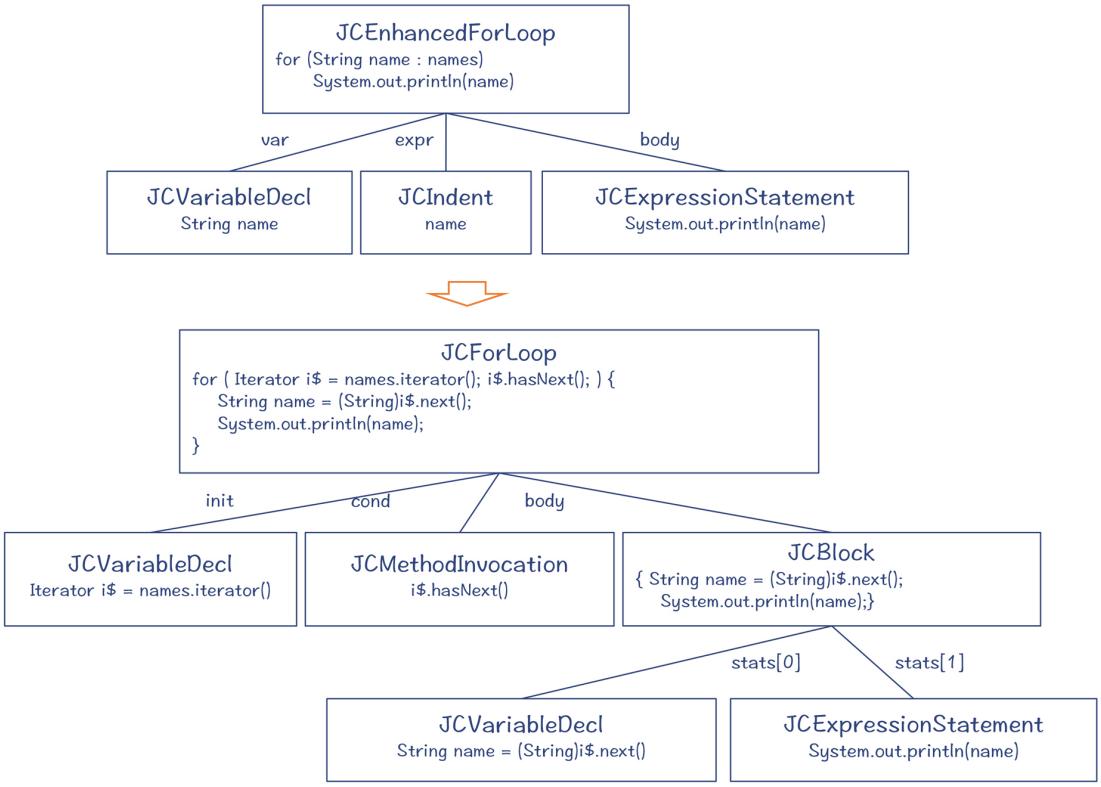

图 2：foreach 循环被改造成普通的 for 循环

你可以通过**反编译**，来获得这些没有语法糖的代码，它跟示例代码中用到的**基础 for 循环语句**是一样的。

对 foreach 循环的处理，是在 **Lower 类的 visitForeachLoop 方法**中。

其实，你在阅读编译技术相关的文献时，应该经常会看到 Lower 这个词。它的意思是，让代码从对人更友好的状态，变换到对机器更友好的状态。比如说，语法糖对编程人员更友好，而基础的语句则相对更加靠近机器实现的一端，所以去除语法糖的过程是 Lower。除了去除语法糖，**凡是把代码向着机器代码方向所做的变换，都可以叫做 Lower。**以后你再见到 Lower 的时候，是不是就非常清楚它的意思了呢。

好了，通过对泛型和 foreach 循环的处理方式的探讨，现在你应该已经大致了解了去除语法糖的过程。总体来说，去除语法糖就是把 AST 做一些变换，让它变成更基础的语法要素，从而离生成字节码靠近了一步。

那么接下来，我们看看编译过程的最后一个环节：生成字节码。

生成字节码（Bytecode Generation）

一般来说，我们会有一个错觉，认为生成字节码比较难。

实际情况并非如此，因为通过前面的建立符号表、属性计算、数据流分析、去除语法糖的过程，我们已经得到了一棵标注了各种属性的 AST，以及保存了各种符号信息的符号表。最难的编译处理工作，在这几个阶段都已经完成了。

在第 8 讲中，我就介绍过目标代码的生成。其中比较难的工作，是指令选择、寄存器分配和指令排序。而这些难点工作，在生成字节码的过程中，基本上是不存在的。在少量情况下，编译器可能会需要做一点指令选择的工作，但也都非常简单，你在后面可以看到。

我们通过一个例子，来看看生成字节码的过程：

复制代码

```
public class MyClass {
    public int foo(int a){
        return a + 3;
    }
}
```

这个例子中，foo 函数对应的字节码有四个指令：

```
public int foo(int);
  Code:
     0: iload_1      //把下标为1的本地变量(也就是参数a)入栈
     1: iconst_3     //把常数3入栈
     2: iadd         //执行加法操作
     3: ireturn      //返回
```

复制代码

生成字节码，基本上就是对 AST 做深度优先的遍历，逻辑特别简单。我们在第 5 讲曾经介绍过栈机的运行原理，也提到过栈机的一个优点，就是生成目标代码的算法比较简单。

你可以看一下我画的示意图，里面有生成字节码的步骤：

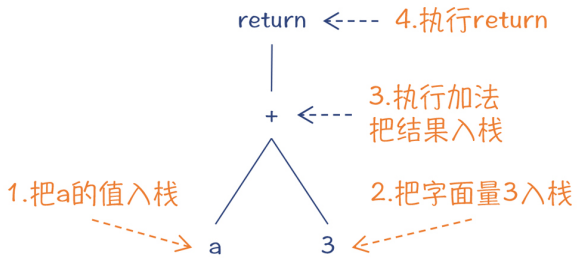

图 3：生成字节码

第 1 步，把 a 的值入栈（iload_1）。

第 2 步，把字面量 3 入栈（iconst_3）。

第 3 步，生成加法运算指令（iadd）。这个操作会把前两个操作数出栈，把结果入栈。

第 4 步，生成 return 指令（ireturn）。

这里面有没有指令选择问题？有的，但是很简单。

首先，你注意一下 iconst_3 指令，这是把一个比较短的操作数压缩到了指令里面，这样就只需要生成一个字节码。如果你把 3 改成一个稍微大一点的数字，比如 7，那么它所生成的指令就要改成“bipush 7”，这样就需要生成两个字节的字节码，一个字节是指令，一个字节是操作数。但这个操作数不能超过“2^7-1”，也就是 127，因为一个字节只能表示 -128~127 之间的数据。

```
0: iload_1
1: bipush        7
3: iadd
4: ireturn
```

如果字面量值变成 128，那指令就要变成“sipush 128”，占据三个字节，表示往栈里压入一个 short 数据，其中操作数占据两个字节。

```
0: iload_1
1: sipush        128
4: iadd
5: ireturn
```

如果该常数超过了两个字节能表示的范围，比如“32768”，那就要改成另一个指令“ldc #2”，这是把常数放到常量池里，然后从常量池里加载。

```
0: iload_1
1: ldc           #2                  // int 32768
3: iadd
4: ireturn
```

这几个例子反映了**由于字面量的长度不同，而选用了不同的指令**。接着，我们再来看看**数据类型对指令的影响。**

前面例子中生成的这四个指令，全部都是针对整数做运算的。这是因为我们已经在语义分析阶段，计算出了各个 AST 节点的类型，它们都是整型。但如果是针对长整型或浮点型的计算，那么生成的字节码就会不一样。下面是针对单精度浮点型所生成的字节码。

```
0: fload_1
1: ldc           #2                  // float 3.0f
3: fadd
4: freturn
```

第三，数据类型影响指令生成的另一个情况，是类型转换。

一方面，阅读字节码的规范，你会发现对 byte、short、int 这几种类型做运算的时候，使用的指令其实是一样的，都是以 i 开头的指令。比如，加载到栈机都是用 iload 指令，加法都是用 iadd 指令。

在示例代码中，我们把 foo 函数的参数 a 的类型改成 byte，生成的字节码与之前也完全一样，你可以自己去试一下。

复制代码

```
public class MyClass {
    public int foo(byte a){
        return a + 3;
    }
}
```

另一方面，在 Java 里把整型和浮点型做混合运算的时候，编译器会自动把整型转化成浮点型。比如我们再把示例代码改成下面这样：

复制代码

```
public class MyClass {
    public double foo(int a){
        return a + 3.0;
    }
}
```

这个时候，foo 函数对应的字节码如下，其中 **i2d 指令**就是把参数 a 从 int 型转换成 double 型：

```
0: iload_1
1: i2d
2: ldc2_w        #2                  // double 3.0d
5: dadd
6: dreturn
```

OK，到这里，我已经总结了影响指令生成的一些因素，包括字面量的长度、数据类型等。你能体会到，这些指令选择的逻辑都是很简单的，基于当前 AST 节点的属性，编译器就可以做成正确的翻译了，所以它们基本上属于“直译”。而我们在第 8 讲中介绍指令选择

算法的时候，遇到的问题通常是结合了多个 AST 节点生成一条指令，它的难度要高得多。所以在第 16 讲，讲解 Java 的 JIT 编译器生成目标代码的时候，我会带你去看看这种复杂的指令选择算法的实现方式。

现在你对生成字节码的基本原理搞清楚了以后，再来看 Java 编译器的具体实现，就容易多了。

生成字节码的程序入口在 **com.sun.tools.javac.jvm.Gen 类**中。这个类也是 AST 的一个 visitor。这个 visitor 把 AST 深度遍历一遍，字节码就生成完毕了。

在 com.sun.tools.javac.jvm 包中，有两个重要的辅助类。

第一个辅助类是 Item。包的内部定义了很多不同的 Item，代表了在字节码中可以操作的各种实体，比如本地变量（LocalItem）、字面量（ImmediateItem）、静态变量（StaticItem）、带索引的变量（IndexedItem，比如数组）、对象实例的变量和方法（MemberItem）、栈上的数据（StackItem）、赋值表达式（AssignItem），等等。

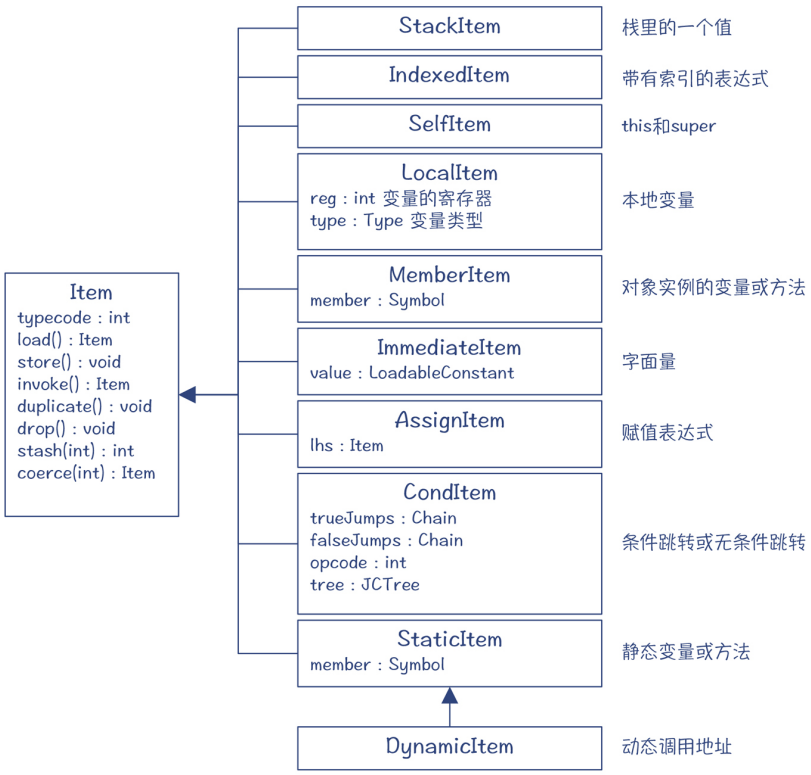

图 4：生成字节码过程中的辅助类 Item 及其子类

每种 Item 都支持一套标准的操作，能够帮助生成字节码。我们最常用的是 load()、store()、invoke()、coerce() 这四个。

load()：生成把这个 Item 加载到栈上的字节码。

我们刚才已经见到了两种 Item 的 load 操作，一个是本地变量 a 的（LocalItem），一个是立即数 3 的（ImmediateItem。在字节码和汇编代码里，如果一个指令的操作数是一个常数，就叫做立即数）。

你可以看一下 ImmediateItem 的 load() 方法，里面准确反映了我们前面分析的指令选择逻辑：根据字面量长度的不同，分别选择 iconst_X、bipush、sipush 和 ldc 指令。

复制代码

```
Item load() {
    switch (typecode) {
    //对int、byte、short、char集中类型来说，生成的load指令是相同的。
    case INTcode: case BYTEcode: case SHORTcode: case CHARcode:
        int ival = numericValue().intValue();
        if (-1 <= ival && ival <= 5)
            code.emitop0(iconst_0 + ival); //iconst_X指令
        else if (Byte.MIN_VALUE <= ival && ival <= Byte.MAX_VALUE)
            code.emitop1(bipush, ival);    //bipush指令
        else if (Short.MIN_VALUE <= ival && ival <= Short.MAX_VALUE)
            code.emitop2(sipush, ival);    //sipush指令
        else
            ldc();                         //ldc指令
        break;
        ...
}
```

load() 方法的返回值，是一个 StackItem，代表加载到栈上的数据。

store()：生成从栈顶保存到该 Item 的字节码。

比如 LocalItem 的 store() 方法，能够把栈顶数据保存到本地变量。而 MemberItem 的 store() 方法，则会把栈顶数据保存到对象的成员变量中。

invoke()：生成调用该 Item 代表的方法的字节码。

coerce()：强制类型转换。

我们之前讨论的类型转换功能，就是在 coerce() 方法里完成的。

第二个辅助类是 Code 类。它里面有各种emitXXX() 方法，会生成各种字节码的指令。

总结起来，字节码生成的总体框架如下面的类图所示：

Gen 类以 visitor 模式访问 AST，生成字节码；最后生成的字节码保存在 Symbol 的 code 属性中。

在生成字节码的过程中，编译器会针对不同的 AST 节点，生成不同的 Item，并调用 Item 的 load()、store()、invoke() 等方法，这些方法会进一步调用 Code 对象的 emitXXX() 方法，生成实际的字节码。

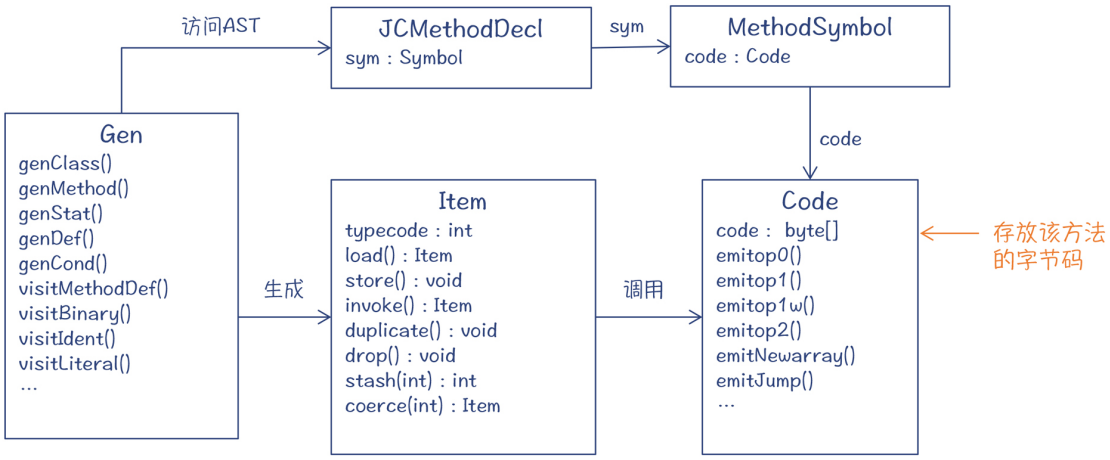

图 5：生成字节码过程中涉及的类

好了，这就是生成字节码的过程，你会发现它的思路是很清楚的。你可以写一些不同的测试代码，观察它生成的字节码，以及跟踪生成字节码的过程，很快你就能对各种字节码是如何生成的了然于胸了。

代码优化

到这里，我们把去除语法糖和生成字节码两部分的内容都讲完了。但是，在 Java 编译器里，还有一类工作是分散在编译的各个阶段当中的，它们也很重要，这就是代码优化的工作。

总的来说，Java 编译器不像后端编译器那样会做深度的优化。比如像下面的示例代码，“int b = a + 3”这行是无用的代码，用一个“死代码删除”的优化算法就可以去除掉。而在 Java 编译器里，这行代码照样会被翻译成字节码，做一些无用的计算。

复制代码

```
int foo(){
  int a = 2;
  int b = a + 3;  //这行是死代码，可以优化掉
  return a;
}
```

不过，Java 编译器还是在编译过程中，顺便做了一些优化：

1.ATTR 阶段：常数折叠

在属性分析阶段做了常数折叠优化。这样，在生成字节码的时候，如果一个节点有常数值，那么就直接把该常数值写入字节码，这个节点之下的子树就都被忽略。

2.FLOW 阶段：不可达的代码

在 FLOW 阶段，通过活跃性分析，编译器会发现某些代码是不可达的。这个时候，Java 编译器不是悄悄地优化掉它们，而是会报编译错误，让程序员自己做调整。

3.LOWER 阶段：代数简化

在 LOWER 阶段的代码中，除了去除语法糖，你还能看到一些代数简化的行为。给你举个例子，在 Lower.visitBinary() 方法中，也就是处理二元操作的 AST 的时候，针对逻辑“或（OR）”和“与（AND）”运算，有一些优化代码。比如，针对“或”运算，如果左子树的值是 true，那么“或”运算对应的 AST 用左子树代替；而如果左子树是的值是 false，那么 AST 可以用右子树代替。

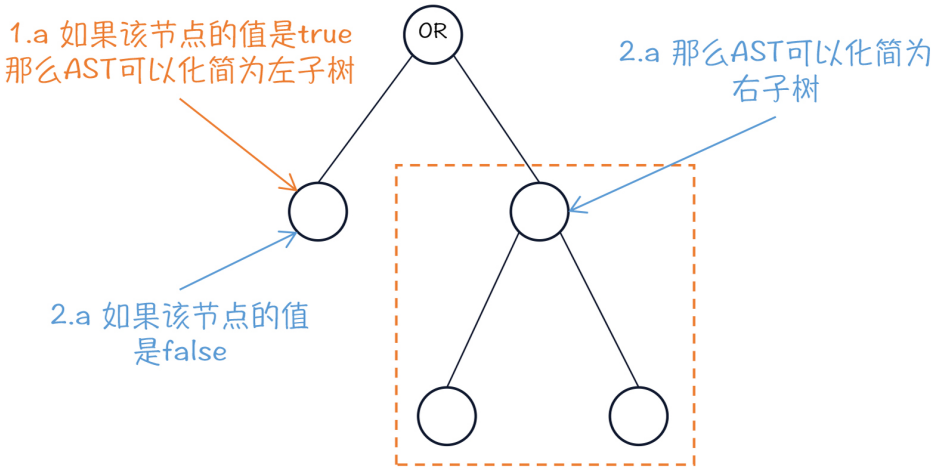

图 6：对 AST 做代数简化

4.GEN 阶段：代数简化和活跃性分析

在生成字节码的时候，也会做一些代数简化。比如在 **Gen.visitBinary() 方法中**，有跟 Lower.visitBinary() 类似的逻辑。而整个生成代码的过程，也有类似 FLOW 阶段的活跃性分析的逻辑，对于不可达的代码，就不再生成字节码。

看上去 GEN 阶段的优化算法是冗余的，跟前面的阶段重复了。但是这其实有一个好处，也就是可以把生成字节码的部分作为一个单独的库使用，不用依赖前序阶段是否做了某些优化。

总结起来，Java 编译器在多个阶段都有一点代码优化工作，但总体来看，代码优化是很不足的。真正的高强度的优化，还是要去看 Java 的 JIT 编译器。这些侧重于做优化的编译器，有时就会被叫做“优化编译器（Optimizing Compiler）”。

课程小结

今天，我带你分析了 Java 编译过程的最后两个步骤：去除语法糖和字节码生成。你需要记住以下几点：

语法糖是现代计算机语言中一个友好的特性。Java 语言很多语法上的升级，实际上都只是增加了一些语法糖而已。语法糖在 Java 编译过程中的去除语法糖环节会被还原成基础的语法。**其实现机制，是对 AST 做修改和转换。**

生成字节码是一个比较机械的过程，**编译器只需要对 AST 进行深度优先的遍历即可。在这个过程中会用到前几个阶段形成的属性信息，特别是类型信息。**

我把本讲的知识点整理成了思维导图，供你参考：

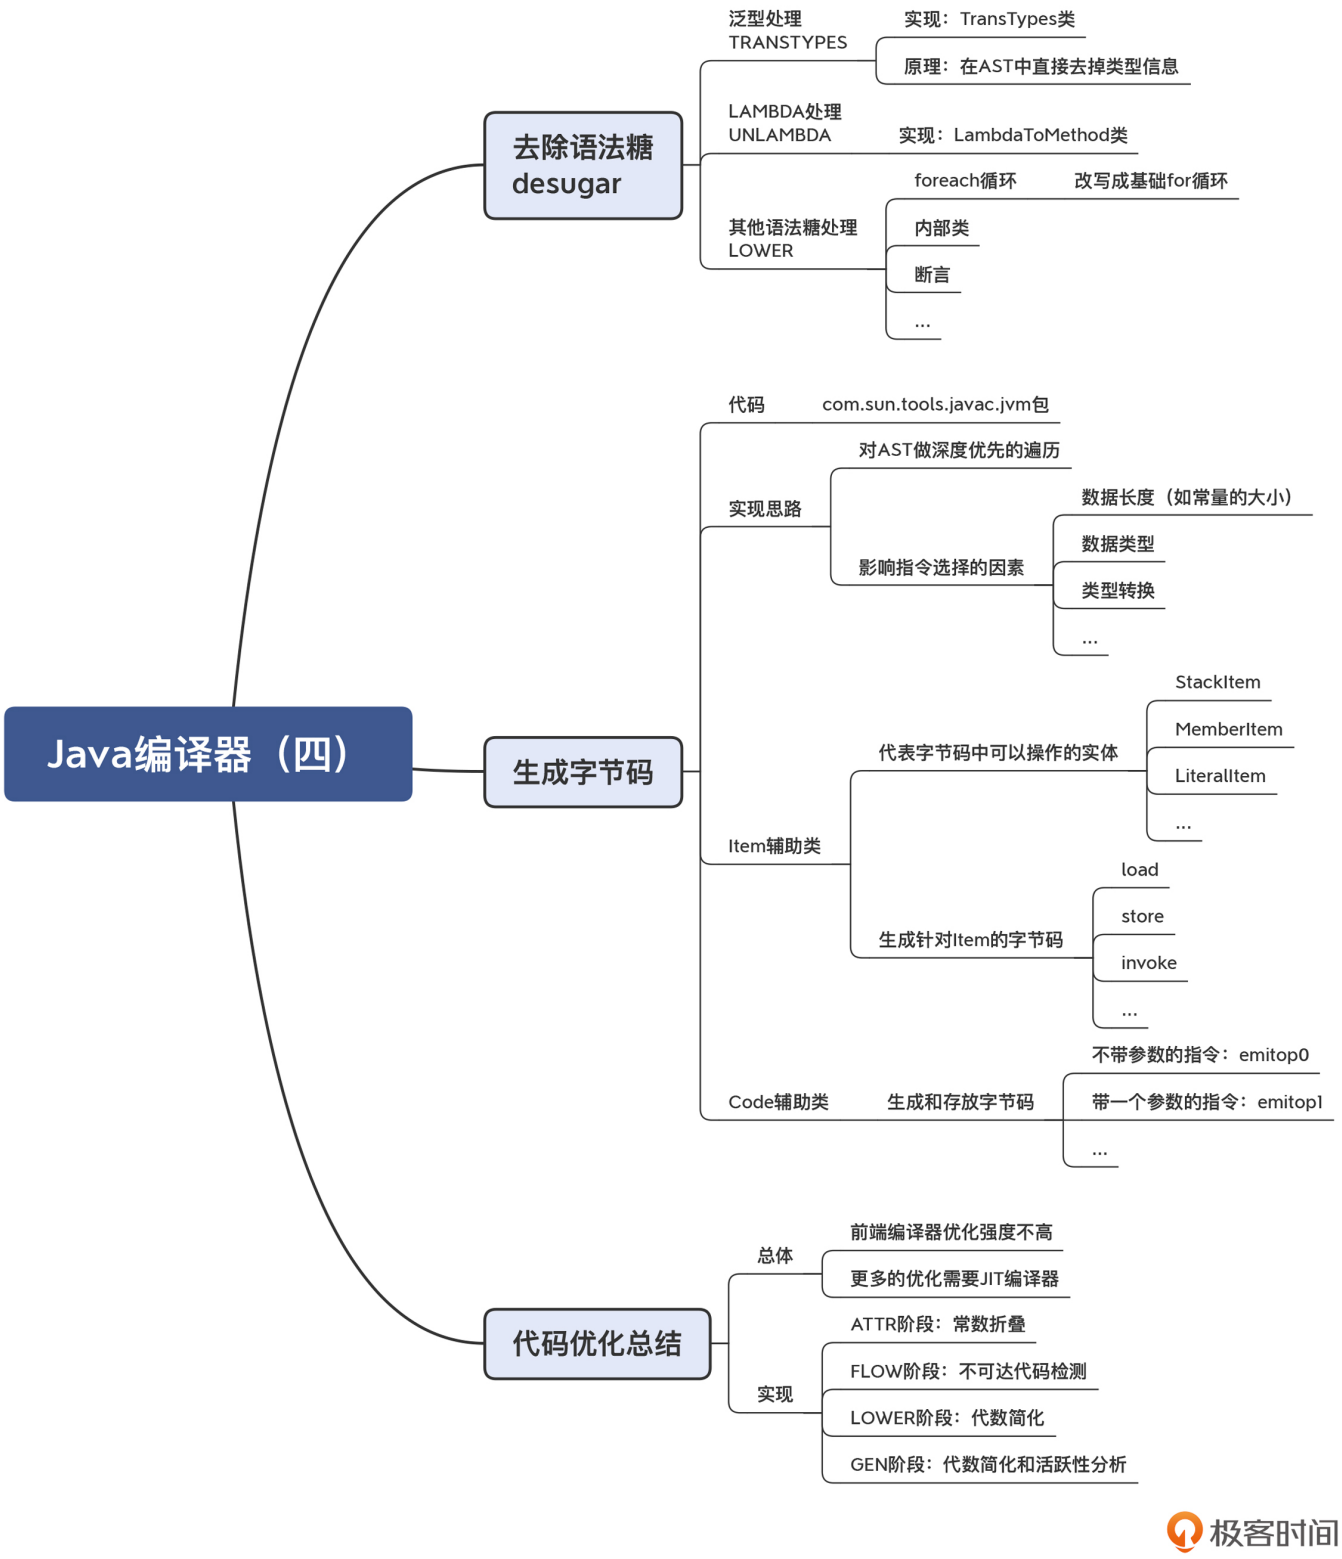

之所以我花了 4 讲去介绍 Java 编译器的核心机制，是因为像 Java 这样成熟的静态类型语言，它的编译器的实现思路有很多借鉴意义，比如词法分析和语法分析采用的算法、语义分

析中多个阶段的划分和之间的相互关系、如何用各种方法检查语义错误、符号表的实现、语法糖和基础语法的关系，等等。当你把 Java 编译器的脉络看清楚以后，再去看其他静态类型语言的编译器的代码，就会发现其中有很多地方是共通的，你就能更快地熟悉起来。这样下来，你对静态语言编译器的前端，都会有个清晰的了解。

当然，只了解前端部分是不够的，Java 还有专注于中后端功能的编译器，也就是 JIT 编译器。我们这讲也已经说过了，前端编译器的优化功能是有限的。那么，如果想让 Java 代码高效运行，就要依靠 JIT 编译器的优化功能和生成机器码的功能了。在后面的四讲中，我会接着给你揭秘 Java 的 JIT 编译器。

一课一思

针对 Java 编译器这 4 讲的内容，我们来做一个综合的思考题。假设你现在要写一个简单的 DSL 引擎，比如让它能够处理一些自定义的公式，最后要生成字节码，你会如何让它最快地实现？是否可以复用 Java 编译器的功能？

欢迎你留言分享自己的观点。如果觉得有收获，也欢迎你把今天的内容分享给更多的朋友。

参考资料

Java 语言规范第六章：Java 虚拟机指令集。

更多课程推荐

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 11 | Java编译器（三）：属性分析和数据流分析

精选留言

写留言

由作者筛选后的优质留言将会公开显示，欢迎踊跃留言。